Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 12, No. 2, Summer 2022, p. 107-118

Identification of *Idiocerus stali* (Hem.: Cicadellidae) Using Image Processing and Artificial Neural Networks

Z. Azizpour[1], H. Vahedi[2], A. N. Lorestani[3*]

1- MSc Student, Plant Protection Department, Agricultural Faculty, Razi University, Kermanshah, Iran
2- Associate Professor, Plant Protection Department, Agricultural Faculty, Razi University, Kermanshah, Iran
3- Associate Professor, Mechanical Engineering of Biosystems Department, Agricultural Faculty, Razi University, Kermanshah, Iran
(*- Corresponding Author Email: lorestani@razi.ac.ir)

Received: 28-05-2019 Revised: 16-11-2019 Accepted: 02-12-2019	**How to cite this article:** Azizpour, Z., H. Vahedi, and A. N. Lorestani. 2022. Identification of *Idiocerus stali* (Hem.: Cicadellidae) Using Image Processing and Artificial Neural Networks. Journal of Agricultural Machinery 12 (2): 107-118. (In Persian). DOI: 10.22067/jam.v12i2.81004.

Introduction

Pistachio or Green Gold is one of the most important agricultural crops and is especially important for Iranian exports. A group of pistachio's pests mainly feed on pistachio, among which *Idiocerus stali* is very important. Conventional methods for identifying insects using identification keys are time-consuming and costly. Due to the rapid development of the Pistachio industry, the use of artificial intelligence techniques such as image processing, for identification and population monitoring is highly recommended. On the other hand, little research was carried out on *I. stali*. Therefore, in this research, *I. stali* was selected as a target insect for the identification and counting on sticky yellow cards using image processing techniques and artificial neural networks. The purpose of this study was to determine the feasibility of *I. stali* identification algorithm by image processing, to determine the possibility of separation and counting of *I. stali* from other non-target insects by artificial neural network and to determine its accuracy in identification of *I. Stali*.

Materials and Methods

Idiocerus stali was selected as the target insect for identification. Sticky yellow cards were used for collecting samples. Taking the photos with the help of a SONY Handycam Camera, which had a 12-megapixel resolution and G lens, was carried out (SONY, HDR-XR500, CMOS, SONY Lens G, Made in Japan). Then insects were counted on each card manually and the data was recorded. The data, which were digital images of yellow sticky cards, were imported into the MatLab R2017b software environment. A total of 357 color properties and 20 shape's features for the identification of *I. stali* were extracted by an image processing algorithm. Color properties were divided into two categories of mean and standard deviation and characteristics related to vegetation indices. An ANN-PSO (Artificial Neural Network hybrid method-Particle Swarm Optimization) algorithm was used to select the effective features. The selected effective characteristics for insect classification were: Color index for extra collective vegetation related to HSL color space, normalized difference index for LCH color space, gray channel for color space YCbCr, second component index minus third component for color space YCbCr, area and mean of the first, second and third components of color space Luv.

Results and Discussion

Comparing the results with the results of Qiao *et al.* (2008), we found that in his study, which divided the data into three categories, for medium and high-density groups, the detection rate was 95.2% and 94.6%, respectively. On the other hand, in low densities (less than 10 trapped insects); its detection rate was 72.9%, while the detection rate of the classifier system designed in this study for different densities of trapped insects, was identical and equal to 99.59%. Also, comparing the results of this study with Espinoza *et al.* (2016), we found that their algorithm in whiteflies detection had a high accuracy of about 0.96 on a sticky yellow card, while the Thrips identification algorithm accuracy was 0.92 on a sticky blue card. As stated above, the correct detection rate of *I. stali* by the algorithm designed in this study was 99.72%.

Conclusion

The results showed the feasibility of the new method for identifying the pest insects without destroying them on the farm and in natural light conditions and in a short time and with very high accuracy. This suggests that this algorithm can be applied to the machine vision system and can be used in future in the construction of agricultural robots.

Keywords: Artificial Neural Network, Classification, Identification, Image processing

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی

جلد ۱۲، شماره ۲، تابستان ۱۴۰۱، ص ۱۱۸-۱۰۷

شناسایی زنجرک پسته *Idiocerus stali* (Hem.: Cicadellidae) با استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعی

زینب عزیزپور[۱]، حسنعلی واحدی[۲]، علی نجات لرستانی[۳*]

تاریخ دریافت: ۱۳۹۸/۰۳/۰۷
تاریخ پذیرش: ۱۳۹۸/۰۹/۱۱

چکیده

استراتژی مدیریت تلفیقی آفات (IPM)، به پایش پیوسته جمعیت آفات وابسته است، این کار نه تنها زمان‌بر است، بلکه وابستگی زیادی به داوری انسان دارد و پر هزینه نیز می‌باشد. استفاده از روش‌های هوش مصنوعی به جای تصمیم‌گیری‌های دستی و انسانی، علاوه بر این که سبب افزایش بهره‌وری می‌گردد، از دقت بالایی نیز برخوردار است. پسته، یک محصول تجاری است و هر ساله خسارت زیادی توسط حشرات به تولیدکنندگان این محصول وارد می‌شود. گروهی از آفات پسته عمدتاً از میوه پسته تغذیه می‌کنند، که از این گروه زنجرک پسته، دارای اهمیت زیادی می‌باشد. در این تحقیق زنجرک پسته به‌عنوان حشره هدف جهت شناسایی انتخاب شد. برای جمع‌آوری نمونه‌ها از کارت‌های زرد چسبنده استفاده شد. ۳۵۷ خصوصیت رنگی و ۲۰خصوصیت شکلی برای شناسایی زنجرک پسته به‌وسیله الگوریتم پردازش تصویر استخراج شد. خصوصیات رنگی به دو دسته‌ی خصوصیات مربوط به میانگین و انحراف‌معیار و خصوصیات مربوط به شاخص‌های سبزی تقسیم شدند. از ۱۷ فضای رنگی مختلف مثل RGB، HSV و غیره برای استخراج خصوصیات و از روش هیبرید شبکه عصبی مصنوعی-الگوریتم بهینه‌سازی ازدحام ذرات (ANN-PSO) برای انتخاب خصوصیات مؤثر استفاده گردید. خصوصیات مؤثر انتخابی جهت طبقه‌بندی حشرات عبارتند از: شاخص رنگی برای پوشش گیاهی استخراجی مربوط به فضای رنگی HSL، شاخص تفاضل نرمال شده مربوط به فضای رنگی LCH، کانال خاکستری مربوط به فضای رنگی YCbCr، شاخص مؤلفه دوم منهای مؤلفه سوم مربوط به فضای رنگی YCbCr، مساحت و میانگین مؤلفه های اول، دوم و سوم فضای رنگی Luv. نرخ شناسایی الگوریتم پردازش تصویر طراحی شده، ۹۹/۷۲درصد کل اشیا (زنجرک پسته، سوسک چوب‌خوار قرمز پسته و سایر حشره‌های غیر هدف و متفرقه) می‌باشد. شبکه‌های عصبی مصنوعی، توانایی طبقه‌بندی حشرات به سه کلاس (زنجرک پسته، سوسک چوب‌خوار قرمز پسته و سایر حشره‌های غیر هدف و متفرقه) و دو کلاس (زنجرک پسته و سوسک چوب‌خوار قرمز پسته) به‌ترتیب با دقت ۹۱/۵۳ و ۹۹/۵۹ درصد را دارند.

واژه‌های کلیدی: پردازش تصویر، زنجرک پسته، شبکه عصبی مصنوعی، شناسایی

مقدمه

پسته یا طلای سبز یکی از محصولات مهم کشاورزی است و در میان محصولات صادراتی ایران، از اهمیت ویژه و اعتبار بالایی برخوردار می‌باشد. ایران بزرگ‌ترین تولیدکننده و صادرکننده پسته در سطح جهانی می‌باشد (Karbasi and Taohidi, 2015). سطح زیر کشت پسته در ایران در سال ۲۰۱۷ میلادی برابر ۴۲۹۵۳۵ هکتار بوده که با برداشت ۵۷۴۹۸۷ تن محصول در آن سال، عملکرد ۱۳۳۸/۶ کیلوگرم بر هکتار به‌دست آمد (FAO, 2017). در باغات پسته آفات متنوعی دیده می‌شود که از قسمت‌های مختلف درخت پسته تغذیه نموده و خسارت می‌زنند. گروهی از آن‌ها عمدتاً از میوه پسته تغذیه می‌کنند، که از این گروه زنجرک پسته[۴]، دارای اهمیت زیادی می‌باشد (Jalilvand and Kashani-Zadeh, 2013)، به‌طوری‌که در باغ‌های آلوده اگر با آن مبارزه نشود، خسارت سنگینی به بار می‌آورد و کاهش معنی‌داری در عملکرد رخ خواهد داد (Mehrnejad, 2001). شناسایی عبارت است از آگاهی از جنس و گونه‌ی هر نمونه از جاندار با بهره‌گیری از مجموعه‌ها و منابع علمی

۱- دانشجوی کارشناسی ارشد، گروه گیاهپزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران
۲- دانشیار گروه گیاهپزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران
۳- دانشیار گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران
(*- نویسنده مسئول: Email: lorestani@razi.ac.ir)
DOI: 10.22067/jam.v12i2.81004

4- Pistachio Leaf hopper

موجود. واژه‌ی شناسایی به‌صورت تعیین هویت و تشخیص نیز بیان می‌شود. برای شناسایی مهم‌ترین وسیله‌ی مورد نیاز تاکسونومیست، کلید شناسایی است. تهیه‌ی کلید شناسایی مستلزم صرف زمان زیادی می‌باشد. معمولاً مشخصات ریخت‌شناسی مثل رنگ بدن، طول بدن، اندازه بدن و غیره بیش از دیگر خصوصیات در طبقه‌بندی مورد استفاده قرار می‌گیرند (Modarres Awal, 2009). تصویر دیجیتالی ماتریسی دو در دو است که هر زوج از اندیس‌های سطری و ستونی آن، یک نقطه از تصویر را مشخص می‌کند. عناصر این ماتریس پیکسل نامیده می‌شوند. برای شناساندن رنگ یک پیکسل به نرم‌افزار، مدل‌های مختلفی وجود دارد که مدل رنگ RGB به دلیل سادگی کار با آن، بهترین مدل بوده و بیشتر از آن استفاده می‌شود. هر پیکسل از یک تصویر رنگی RGB، دارای سه مؤلفه به نام‌های مؤلفه قرمز[1]، سبز[2] و آبی[3] می‌باشد. این اجزا متناسب با نوع کلاس داده، مقادیر محدودی خواهند داشت. به‌عنوان مثال در صورتی که تصویر RGB در کلاس داده double، unit8 یا unit16 باشد به‌ترتیب دارای مقادیری بین صفر و یک، صفر و ۲۵۵ یا صفر و ۶۵۵۳۵ می‌باشند. سایر فضاهای رنگی با استفاده از این فضای رنگی درست شده‌اند. به‌طور کلی به عملیاتی که قبل از پردازش اصلی تصویر دیجیتال صورت می‌گیرد، پیش‌پردازش گویند. به‌عنوان مثال تغییر مقیاس تصویر، چرخش تصویر، استخراج نواحی مورد نظر در یک تصویر و غیره. از طرفی دیگر، به مجموعه عملیاتی که بعد از اجرای بخشی از پردازش تصویر صورت می‌گیرد، عملیات پس‌پردازش گویند. به‌عنوان مثال، به‌منظور استخراج خصوصیات شکلی نیاز به تبدیل تصویر دودویی می‌باشد (Gonzalez and Woods, 2018). فرآیند پردازش تصویر در چهار مرحله پیش‌پردازش، استخراج خاصیت[4]، انتخاب خاصیت و طبقه‌بندی هوشمند انجام می‌گیرد. ابتدا از یک یا چند نمونه مورد مطالعه، با استفاده از دوربین دیجیتال، تصویر تهیه می‌شود. گام بعدی پردازش تصویر است، که تصاویر رنگی را به تصاویر سیاه و سفید تبدیل می‌کنند، سپس به تصویر باینری تبدیل می‌شوندکه تنها شامل دو بخش سیاه و سفید است که طی آن، ناحیه مورد نظر از پس زمینه تصویر جدا می‌شود (Solomon and Breckon, 2011). سپس استخراج خاصیت صورت می‌گیرد و خاصیت‌های استخراج شده طبقه‌بندی می‌شوند. طبقه‌بندهای مختلفی همچون شبکه‌های عصبی مصنوعی[5] می‌توانند مورد استفاده قرار گیرند (Ghaiwat and Arora, 2014). یکی از مهم‌ترین خصوصیات به‌منظور قطعه‌بندی و همچنین طبقه‌بندی، خصوصیات رنگی است. بیست خصوصیت شکلی مختلف از جمله طول، عرض، مساحت، محیط، لگاریتم نسبت طول به عرض، نسبت محیط شکل به محیط مستطیل در برگیرنده شکل، نسبت عرض به طول، نسبت مساحت به طول، خروج از مرکزیت، تمایل، سطح محدب[6]، سطح یکپارچه، قطر معادل، عدد اویلر، یکپارچگی، محدوده[7]، کشیدگی، فشردگی، نسبت تصویر و نسبت طول به محیط استخراج می‌شوند. انتخاب خصوصیات مؤثر در میان خصوصیات استخراج شده به‌منظور طبقه‌بندی بسیار پراهمیت می‌باشد. روش‌های مختلفی برای انتخاب خصوصیات مؤثر مثل هیبرید شبکه عصبی مصنوعی– الگوریتم بهینه‌سازی ازدحام ذرات[8]، وجود دارد (Gonzalez *et al.*, 2004). شبکه‌های عصبی مصنوعی از عناصر عملیاتی ساده‌ای به‌صورت موازی ساخته می‌شوند. این عناصر از سیستم‌های عصبی زیستی الهام گرفته‌اند. در طبیعت، ساختار شبکه‌های عصبی از طریق نحوه اتصال بین اجزا تعیین می‌شود. بنابراین می‌توان یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی ساخت و با تنظیم مقادیر هر اتصال تحت عنوان وزن اتصال نحوه ارتباط بین اجزای آن را تعیین نمود. پس از تنظیم یا همان آموزش شبکه عصبی، اعمال یک ورودی خاص به آن منجر به دریافت پاسخ خاص می‌شود. شبکه بر مبنای تطابق و هم‌سنجی بین ورودی و هدف سازگار می‌شود تا این‌که خروجی شبکه و هدف بر هم منطبق گردند. عموماً تعداد زیادی از این زوج‌های ورودی و خروجی به‌کار گرفته می‌شوند تا در این روند، که از آن تحت عنوان یادگیری نظارت شده یاد می‌شود، شبکه آموزش داده شود. جهت آموزش مدل به شبکه از روش آموزش لونبرگ–مارکوارت[9] استفاده می‌شود، زیرا این روش آموزش دارای سرعت و دقت بالاتری از الگوریتم پس‌انتشار[10] استاندارد می‌باشد و داده‌های ورودی کمتری برای آموزش نیاز دارد. پس از تکمیل آموزش، شبکه طراحی شده بایستی توانایی تعمیم به کل مجموعه و آن‌هایی که در آموزش شرکت نداشته‌اند، را داشته باشد (Kia, 2009).

تحقیقات زیادی در خصوص شناسایی حشرات با پردازش تصویر انجام شده که چند مورد آن به شرح زیر آمده است. چو و همکاران (Cho *et al.*, 2007) به شناسایی خودکار سفیدبالک‌ها، شته‌ها و تریپس‌ها با استفاده از پردازش تصاویر پرداختند. شناسایی خودکار حشرات انتخابی آفت در گلخانه‌ها، روی نمونه‌های جمع‌آوری شده بر روی تله‌های چسبنده زرد انجام شد. اندازه (مساحت) و مؤلفه‌های رنگی اشیاء (میانگین مؤلفه‌های R، G و B) به‌عنوان خصوصیات شناسایی خودکار انتخاب شدند. شته‌ها به آسانی شناسایی شدند زیرا اختلاف کمی در اطلاعات مربوط به رنگ آن‌ها مشاهده شد و اندازه بدن آن‌ها تفاوت قابل ملاحظه‌ای با حشره‌های دیگر داشت. پس از شناسایی شته‌ها، خطای شناسایی برای داده‌های مربوط به تریپس و

1- Red (R)
2- Green (G)
3- Blue (B)
4- Feature Extraction
5- Artificial Neural Networks (ANN)

6- Convex Area
7- Extent
8- Artificial Neural Network- Particle Swarm Optimization algorithm (ANN-PSO)
9-Levenberg- Marquardt (LM)
10- Backpropagation (BP)

سفیدبالک کاهش یافت. مقادیر مرجع اندازه و مؤلفه‌های رنگی نمونه‌برداری شده از ۵۰ حشره، برای هر حشره جهت شناسایی و شمارش استفاده شد. دقت شناسایی الگوریتم برای سفیدبالک‌ها، شته‌ها و تریپس‌ها به‌ترتیب ۹۳/۹۶، ۹۲/۷۳ و ۸۸/۹ درصد به‌دست آمد. ایشان اظهار داشتند که اگر از کارت‌های زرد چسبنده یکپارچه (بدون شبکه‌بندی) استفاده شود، دقت کار بیشتر خواهد شد (Cho *et al.*, 2007). بویسارد و همکاران (Boissard *et al.*, 2008) برای شناسایی سریع و شمارش خودکار آفت گلخانه‌ای سفیدبالک از سیستم پردازش تصویر به‌صورت عکس‌برداری در محل و در شرایط نور طبیعی، استفاده نمودند. آن‌ها از سفیدبالک‌های بالغ چسبیده به زیر برگ‌های گل رز (به تعداد ۲۰ برگ) عکس تهیه نمودند. آن‌ها در این تحقیق از مشخصه‌های رنگ (فضای رنگی HSL که مشابه HSI می‌باشد)، شکل (گرد بودن، خروج از مرکزیت، چهار گوش بودن، کشیده بودن، محدب بودن و فشردگی تصویر حشره) و اندازه (مساحت، طول و محیط) حشره که از تصویرها به کمک پردازش تصویر استخراج گردید، برای شناسایی و شمارش سفیدبالک‌ها استفاده نمودند. لازم به ذکر است که ایشان از ۱۲ خاصیت و ۲۰ نمونه برای استخراج خصوصیات تصویر جهت شناسایی و شمارش در الگوریتم پردازش تصویر استفاده نمودند. ایشان اظهار داشتند که شمارش دستی به‌وسیله انسان به آزمایشگاه و شرایط نورپردازی مناسب و وسایلی مثل ذره‌بین و غیره نیاز دارد، از طرفی چون شمارش حشرات کاری تکراری است، بعد از مدتی شخص خسته شده و از دقت کار کاسته می‌شود ولی سیستم شمارش خودکار که با الگوریتم پردازش تصویر تدارک دیده شده است، ضمن داشتن دقت و سرعت بالا هیچ کدام از مشکلات و محدودیت‌های شمارش توسط انسان را ندارد. در ضمن دقت الگوریتم پردازش تصویر پیشنهاد شده برای شناسایی و شمارش سفیدبالک‌ها، در مقایسه با شمارش چشمی، ۸۳٪ گزارش گردید (Boissard *et al.*, 2008). کیائو و همکاران (Qiao *et al.*, 2008) اظهار داشتند که پیش‌بینی دقیق تراکم آفت برای مدیریت مؤثر آفت ضروری است. آن‌ها آزمایش‌ها را در آزمایشگاه و گلخانه انجام دادند. ۸۱ کارت زرد چسبناک (۱۳ cm در ۱۸ cm) با خطوط سبز رنگ شبکه‌بندی شده در ۹ ردیف به فاصله ۲ متر از همدیگر در روی بوته‌های گوجه‌فرنگی در گلخانه به‌کار بردند. نمونه‌ها به‌وسیله کارت‌های زرد چسبناک از گلخانه‌ای جمع‌آوری شدند، که بعد الگوریتم پردازش تصویر را در آن‌جا پیاده سازی نمودند. سپس تصاویر دیجیتال (۲۰۰ dpi) را با استفاده از اسکنر از کارت‌های زرد رنگ چسبناک تهیه نمودند. با استفاده از سیستم پردازش تصویر به‌طور خودکار تراکم سفیدبالک‌ها بر روی کارت‌های زرد چسبناک را تخمین زدند. تراکم‌های تخمین زده شده نمونه‌ها در آزمایشگاه و گلخانه با مقادیر واقعی هم‌خوانی داشتند. نرخ تشخیص در کارت‌های زرد چسبناک با تعداد حشره ۳۹ تا ۱۴۹ عدد در روی هر کارت و در آزمایشگاه، تقریباً ۹۷/۵درصد بود. ضریب همبستگی بین داده‌های واقعی و تخمین زده شده ۰/۹۹۹ بود (P<0.0001) (Qiao *et al.*, 2008). باربدو (Barbedo, 2014) از تکنیک پردازش تصویر برای شمارش سفیدبالک روی برگ‌های سویا استفاده کرد. وی از ۷۴۸ تصویر از برگ‌های سویا برای این کار استفاده نمود. میزان آلودگی این برگ‌ها از کاملاً سالم و بدون آفت تا کاملاً آلوده، متغیر بود. تصاویر با استفاده از یک دوربین ۱۰ مگاپیکسل گرفته شدند. تصاویر گرفته شده ۳۶۴۸ پیکسل عرض و ۲۷۳۶ پیکسل ارتفاع داشتند که به فرمت JPEG و در فضای رنگی RGB بودند. نشان داده شد که شمارش اکثر هدف‌ها می‌تواند کاملاً به‌طور خودکار انجام شود و سیستم پیشنهادی هنوز سریع‌تر از شمارش دستی است. الگوریتم پیشنهاد شده قادر بود نه تنها سفیدبالک‌های بالغ را تشخیص داده و شمارش نماید، بلکه نمونه‌ها در مرحله پورگی را نیز با دقت ۹۸/۳درصد تشخیص دهد. اگرچه این الگوریتم به‌طور کامل با استفاده از برگ‌های سویا توسعه یافته، اما می‌توانند به آسانی برای انواع محصولات دیگر نیز با کمی تغییر توسعه داده شود. این سیستم چون عملیات پردازش تصویر را به خدمت می‌گیرد، لذا می‌تواند در هر بسته نرم‌افزاری پردازش تصویری اعمال شود (Barbedo, 2014). اسپینوزا و همکاران (Espinoza *et al.*, 2016) از ترکیب پردازش تصویر و شبکه‌های عصبی مصنوعی به‌عنوان یک دستاورد جدید، برای شناسایی سفیدبالک[1] (*Bemisia tabaci*) و تریپس[2] (*Frankliniella occidentalis*) بالغ به‌ترتیب روی کارت‌های چسبنده زرد رنگ و آبی یکپارچه (بدون شبکه‌بندی) برای اجتناب از ایجاد نویز در عکس‌برداری دیجیتال، در گلخانه‌های کشاورزی استفاده نمودند. آن‌ها ۹۰۳ کارت زرد چسبناک و ۶۹۰ کارت آبی چسبناک داشتند. بعد از شمارش دستی سفیدبالک‌ها و تریپس‌های روی کارت‌های رنگی، از آن‌ها عکس گرفته شد. الگوریتم شناسایی سفیدبالک دقت بالایی در حدود ۰/۹۶ روی کارت زرد چسبناک داشت، در حالی‌که الگوریتم شناسایی تریپس دقتی در حدود ۰/۹۲ روی کارت آبی چسبناک داشت (Espinoza *et al.*, 2016). حیدری و امیری پریان (Heidari and Amiri Parian, 2019) در مطالعه‌ای شناسایی و شمارش خودکار آفات مهم گلخانه (سفید بالک و تریپس) از طریق کارت‌های چسبناک زرد رنگ به کمک پردازش تصویر را انجام دادند. از کارت‌های زرد رنگ در طول روز به کمک دوربین دیجیتال عکس گرفته شد. الگوریتم پیشنهاد شده قادر به تشخیص آفات سفید بالک و تریپس و نیز شمارش تعداد آن‌ها بود. برخی مؤلفه‌های رنگی و اندازه اشیاء برای شناسایی خودکار انتخاب شدند. به کمک روش ماتریس اغتشاش، دقت الگوریتم پیشنهاد شده برابر با ۹۴/۵ و ۸۷/۲ درصد به‌ترتیب برای شناسایی حشرات سفید بالک و تریپس محاسبه شد (Heidari and Amiri Parian, 2019).

روش‌های مرسوم برای شناسایی حشرات با استفاده از کلید

1-Whitefly
2-Thrips

شناسایی زمان‌بر و پر هزینه هستند. استفاده از روش‌های هوش مصنوعی به جای تصمیم‌گیری‌های دستی و انسانی، علاوه بر این‌که سبب افزایش بهره‌وری می‌گردد، از دقت بالایی نیز برخوردار است. از طرفی در خصوص زنجرک پسته تحقیقات انگشت‌شماری یافت شد، لذا در این تحقیق زنجرک پسته، به‌عنوان حشره هدف برای شناسایی، طبقه‌بندی و شمارش آن روی کارت زرد، انتخاب شد و از تکنیک‌های پردازش تصویر و شبکه عصبی مصنوعی، که دارای سرعت و دقت بالایی می‌باشند، جهت شناسایی و طبقه‌بندی استفاده می‌شود. هدف از این تحقیق امکان‌سنجی تدوین الگوریتم شناسایی زنجرک پسته به کمک پردازش تصویر، بررسی امکان طبقه‌بندی و شمارش آفت زنجرک پسته شناسایی شده از سایر حشرات غیر هدف به کمک شبکه عصبی مصنوعی و تعیین دقت آن می‌باشد.

مواد و روش‌ها

این تحقیق در زمینی به مساحت ۱۰۰۰ مترمربع در باغ پسته ۴۵ ساله با تراکم ۹۰۰ درخت بر هکتار پردیس کشاورزی و منابع طبیعی دانشگاه رازی انجام گرفت. این باغ پسته آلوده به آفاتی چون زنجرک پسته بود و سم‌پاشی نشده بود. برای جمع‌آوری نمونه‌ها از ۱۰۵ کارت زرد چسبناک یکپارچه (Daegil Co Ltd., Made in Korea) (بدون شبکه‌بندی) به ابعاد ۲۵۰mm*۱۰۰ mm استفاده شد. حشره مورد مطالعه زنجرک پسته (Hem.:Cicadellidae) *Idiocerus stali* Fieber, 1868 (Mozaffarian and Wilson, 2016) بود. نمونه‌برداری در تیر و مردادماه ۱۳۹۶ انجام گردید. هر روز صبح زود کارت‌های زرد رنگ روی درختان پسته آلوده به آفت زنجرک پسته نصب می‌شدند. بعد از حدود ۶ ساعت کارت‌ها از سطح باغ پسته جمع‌آوری شده با یک شماره، هر کارت را از بقیه متمایز نموده و تحت شرایط نور آفتاب از آن‌ها عکس گرفته شد. عکس‌برداری به کمک دوربین هندی‌کم SONY مدل HDR-XR500 ساخت کشور ژاپن، دارای لنز G سونی با رزولوشن ۱۲ مگاپیکسل (SONY, HDR-X500, CMOS, SONY Lens G, Made in Japan) انجام شد. ابتدا حشرات روی کارت‌های چسبنده زرد رنگ توسط متخصصین حشره‌شناسی شناسایی و بعد به‌طور چشمی نیز حشرات روی هر کارت شمارش شده و داده‌ها ثبت گردید. لازم به ذکر است که علاوه بر *I. stali*، که حشره مورد مطالعه بود، حشره دیگری نیز با نام *Anthaxia* Sp. Eschscholtz, 1829 (Coleoptera: Buprestidae) (Baiocchi, 2013)، روی کارت زرد به دام افتاده بود، که مورد بررسی قرار گرفت. داده‌ها که تصاویر دیجیتال از کارت‌های زرد چسبناک بودند، به محیط نرم‌افزار متلب MatLab R2017b فراخوانده شدند. در این نرم‌افزار با توجه به برنامه‌نویسی انجام شده، تصاویر ابتدا پیش‌پردازش شده، نویزها (قسمت‌هایی از پس‌زمینه که به‌صورت اشتباهی حشره تشخیص داده شد) و بی‌نظمی‌ها حذف شدند، سپس به فضاهای رنگی مختلف تبدیل شدند. بعد با توجه به تعداد کانال‌ها، از هر تصویر تعداد ۳۷۷ خصوصیت رنگی و شکلی استخراج شد. آماره‌های مینیمم، میانگین، ماکزیمم، انحراف معیار و واریانس برای خصوصیات استخراجی اعمال شد. این خصوصیات در فضاهای مختلف رنگی مورد بررسی قرار گرفتند و از بین آن‌ها خصوصیاتی که بیشترین تأثیر را در شناسایی و طبقه‌بندی داشتند، به‌عنوان خصوصیات مؤثر انتخاب شدند، که این خصوصیات مؤثر ورودی‌های شبکه عصبی مصنوعی برای طبقه‌بندی بودند. خصوصیات مؤثر توسط الگوریتم هیبرید شبکه عصبی مصنوعی- بهینه‌سازی ازدحام ذرات انتخاب شدند و روش کار چنین است که ابتدا کل خصوصیات استخراجی به عنوان یک بردار در نظر گرفته می‌شود. در مرحله بعد با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات از میان این بردار، بردارهای دیگر با اندازه‌های مختلف انتخاب و به شبکه عصبی مصنوعی ارسال می‌گردند. این بردارها به‌عنوان ورودی‌ها به شبکه عصبی مصنوعی پرسپترون چند لایه ارسال می‌شوند. خروجی شبکه عصبی مصنوعی پرسپترون چند لایه شامل کلاس‌ها می‌باشد. در نهایت میانگین مربعات خطای مربوط به هر برداری که توسط الگوریتم بهینه‌سازی ازدحام ذرات به شبکه عصبی مصنوعی پرسپترون چندلایه ارسال می‌گردد، ثبت می‌شود. هر بردار انتخابی توسط الگوریتم بهینه‌سازی ازدحام ذرات که دارای کمترین مقدار میانگین مربعات خطا باشد، به‌عنوان خصوصیت مؤثر انتخاب می‌گردد. الگوریتم بهینه‌سازی ازدحام ذرات از الگوی حرکات دسته‌جمعی پرندگان برای حل مسائل، تقلید می‌کند. دسته پرندگان در حال پرواز را در نظر بگیرید که هر کدام ضمن حفظ فاصله خود با همسایگان، سرعت را نیز حفظ می‌کنند. زمانی که منبع غذایی یا موقعیتی برای استراحت پیدا می‌کنند، به‌طور ناگهانی تغییر جهت داده و در مکان مورد نظر فرود می‌آیند. پس در این الگوریتم، اجتماع پرندگان به‌صورت ازدحام ذرات در نظر گرفته شده است و هر پاسخ مسئله را یک ذره فرض نموده که هر ذره نیز مدام در حال جستجو و جابه‌جایی با حفظ سرعت می‌باشد. حرکت ذره به موقعیت کنونی ذره، بهترین موقعیتی که ذره تاکنون داشته و بهترین موقعیتی که کل مجموعه ذرات تاکنون داشته‌اند، بستگی دارد (Kennedy and Eberhart, 1995). یکی از مهم‌ترین مراحل پردازش تصویر قطعه‌بندی[1] می‌باشد. در صورتی که عملیات قطعه‌بندی دارای دقت بالایی نباشد، ممکن است که بخش‌هایی از پس‌زمینه به‌عنوان حشره تشخیص داده شود و برعکس، که در نهایت منجر به کاهش دقت، افزایش زمان انجام عملیات محاسبات و کاهش کارآیی سیستم ماشین بینایی می‌شود. ابتدا تصویر یک کارت را انتخاب نموده که در فضای رنگی RGB تهیه شده است (شکل ۱). تصویر مورد نظر از فضای رنگی RGB به فضای رنگی CMY تبدیل می‌شود (شکل ۱). سپس آستانه $Y(i,j)<200$ اعمال می‌شود. این آستانه بیان می‌کند هر پیکسل در فضای رنگی CMY با مقدار مؤلفه سوم (Y) کمتر از ۲۰۰، عضو کارت می‌باشد و باید باقی بماند. مقدار آستانه از طریق سعی و خطا در هنگام برنامه‌نویسی جهت پردازش تصویر تعیین شد. این

1- Segmentation

آستانه برای حالتی که علاوه بر کارت، قسمت‌های دیگری از زمین در حوزه دید دوربین قرار دارند، دارای کاربرد می‌باشد. مرحله بعد اعمال آستانه زیر (رابطه ۱) بر روی تصویر مرحله قبل برای حذف پس‌زمینه می‌باشد (شکل ۲). این آستانه بیان می‌کند که اگر مؤلفه اول پیکسلی بزرگ‌تر از ۱۱۰ و مؤلفه دوم پیکسلی بزرگ‌تر از ۱۱۰ و مؤلفه سوم پیکسلی بزرگ‌تر از ۱۰۵ و قدر مطلق تفاضل مؤلفه اول و دوم پیکسلی کمتر از ۱۰ یا مؤلفه اول بزرگ‌تر از ۱۵۰ باشد، آن پیکسل جزو پس زمینه می‌باشد و باید حذف گردد.

$$(TBW1(i,j)>110 \ \& \ TBW2(i,j)>110 \ \& \ TBW3(i,j)>105 \ \& \ abs(TBW1(i,j)-TBW2(i,j))<10) \ | TBW1(i,j)>150 \quad (۱)$$



شکل ۱- تصویر یک کارت زرد چسبناک در فضای رنگی RGB (سمت راست) و تبدیل تصویر RGB به فضای رنگی CMY (سمت چپ)

Fig.1. Images of a sticky yellow card in RGB color space (Right) and the converted RGB image to CMY color space (Left)



شکل ۲- اعمال آستانه برای حذف پس‌زمینه (سمت راست) و کارت زرد پردازش شده که اشیاء با شماره مشخص شده‌اند (سمت چپ)

Fig.2. Applied thresholds to remove the background (Right) and processed yellow card with objects marked with the number (Left)

در این تحقیق هدف شناسایی زنجرک پسته بود، پس در نهایت داده‌ها به دو کلاس طبقه‌بندی شدند که برای این کار در جعبه‌ابزار شبکه‌های عصبی مصنوعی نرم‌افزار متلب، از شبکه عصبی پرسپترون چندلایه[1]، با ۳ لایه، ۳۸ نورون، ۳ تابع انتقال satlins، tansig و tansig به‌ترتیب در لایه‌های اول، دوم و سوم با تابع آموزش شبکه پس‌انتشار برگشتی، trainlm و تابع یادگیری وزن/بایاس پس‌انتشار برگشتی، learnsom مطابق جدول ۱ استفاده شد. ۶۰ درصد از داده‌ها به‌صورت تصادفی برای آموزش، ۲۰ درصد برای آزمون و ۲۰ درصد نیز برای اعتبارسنجی استفاده گردید.

جدول ۱- مقادیر پارامترهای شبکه عصبی پرسپترون چندلایه برای لایه‌های پنهان جهت طبقه‌بندی به دو کلاس

Table 1- Parameters' values of the multilayer perceptron neural network for hidden layers for classification into two classes

Neurons **نرون‌ها**	**First Layer: 18, Second Layer: 13, Third Layer: 7** **لایه اول: ۱۸، لایه دوم: ۱۳، لایه سوم: ۷**
Number of Layers تعداد لایه‌ها	3
Transfer Functions توابع انتقال	First Layer: satlins, Second Layer: tansig, Third Layer: tansig لایه اول: satlins، لایه دوم: tansig، لایه سوم: tansig
Backward back propagation network training function تابع آموزش شبکه پس‌انتشار برگشتی	Trainlm
Backward back propagation Weight / Bias learning function تابع یادگیری وزن/بایاس پس‌انتشار برگشتی	Learnsom

1- Multi-Layer Perceptron (MLP)

جهت بررسی عملکرد و کارآیی سیستم طبقه‌بند بـه‌کـار رفتـه در ایـن الگـوریتم از مـاتریس اغتشـاش[۱]، دقـت طبقـه‌بنـدی و نمـودار خصوصیت عملیاتی دریافت‌کننده (ROC)[۲] استفاده می‌شود. مـاتریس اغتشاش، ماتریسی است مربعی که به تعداد کلاس‌ها، سطر و سـتون دارد. دقت طبقه‌بندی بر مبنای کل داده‌هایی که درسـت طبقـه‌بنـدی شده‌اند، ارائه شده است. عملکرد الگوریتم‌هـای طبقـه‌بنـدی، معمـولاً توسط ارزیابی حساسیت[۳]، خاصیت[۴] و دقت[۵] بررسـی مـی‌گردنـد. سـه معیار حساسیت، خاصیت و دقت به‌ترتیب با استفاده از روابط (۲) تا (۴) تعریف می‌شوند (Kazmi *et al.*, 2015):

$$Sensitivity = \frac{TP}{TP + FN} \quad (۲)$$

$$Specificity = \frac{TN}{TN + FP} \quad (۳)$$

$$Accuracy = \frac{TP + TN}{N} \quad (۴)$$

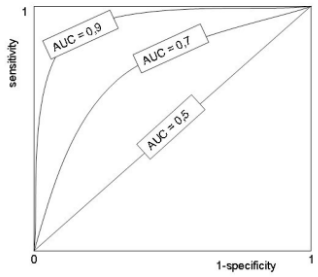
در این روابط:

Sensitivity، حساسـیت (بـر حسـب درصـد)، Specificity، خاصیت (بر حسب درصد) و Accuracy، دقت کل می‌باشد (بر حسب درصد)، N برابر تعداد کل نمونه‌ها، TP برابر است با تعداد نمونه‌هـای هر کلاس، که درست طبقه‌بندی شده‌اند. TN برابـر اسـت بـا تعـداد نمونه‌های کلاس‌های دیگر غیر از کلاس مورد نظر، کـه بـه درسـتی طبقه‌بندی شده‌اند. FN برابر است با مجموع نمونه‌های کلاس مـورد نظر، که به درستی در کلاس مورد نظر طبقه‌بندی نشده‌اند یا به طـور نادرست در کلاس‌های دیگر طبقه‌بندی شده‌انـد. FP برابـر اسـت بـا مجموع نمونه‌های کلاس‌های دیگر، که به طور نادرسـت در کـلاس مورد نظر طبقه‌بندی شده‌اند (Kazmi *et al.*, 2015).

شکل منحنی ROC و سطح زیر منحنی[۶] به ما در تخمین این‌که توان تشخیص یک سیستم طبقه‌بند چه‌قدر است، کمک می‌کنـد. هـر قدر منحنی به گوشه بالا سمت چپ نزدیـک‌تـر باشـد و سـطح زیـر منحنی بزرگ‌تر باشد، سیستم طبقه‌بند عملکرد بهتری دارد (شکل ۳). سطح زیر منحنی می‌تواند مقداری بین صفر و یک داشته باشد و ایـن یک شاخص خوب برای ارزیابی سیستم طبقه‌بند است. یـک سیسـتم طبقه‌بند عالی سطح زیر منحنـی برابـر یـک را دارد (AUC=1.0). در صورتی‌که یـک سیسـتم طبقـه‌بنـد ضـعیف سـطحی برابـر نـیم دارد (AUC=0.5). به‌طور کلی رابطه بین AUC و دقت تشـخیص طبـق داده‌های جدول ۲ است (Šimundić, 2009).

جدول ۲- رابطه بین سطح زیر منحنی ROC و دقت تشخیص
Table 2- The relationship between the area under the ROC curve and the accuracy of detection

Area سطح	Diagnostic accuracy دقت تشخیص
0.9-1.0	Excellent عالی
0.8-0.9	Very good خیلی خوب
0.7-0.8	Good خوب
0.6-0.7	Sufficient کافی
0.5-0.6	Bad بد
< 0.5	Test not useful آزمون مفید نیست



شکل ۳- منحنی خصوصیت عملیاتی دریافت‌کننده (ROC)
Fig.3. Receiver Operating Characteristic (ROC) Curve

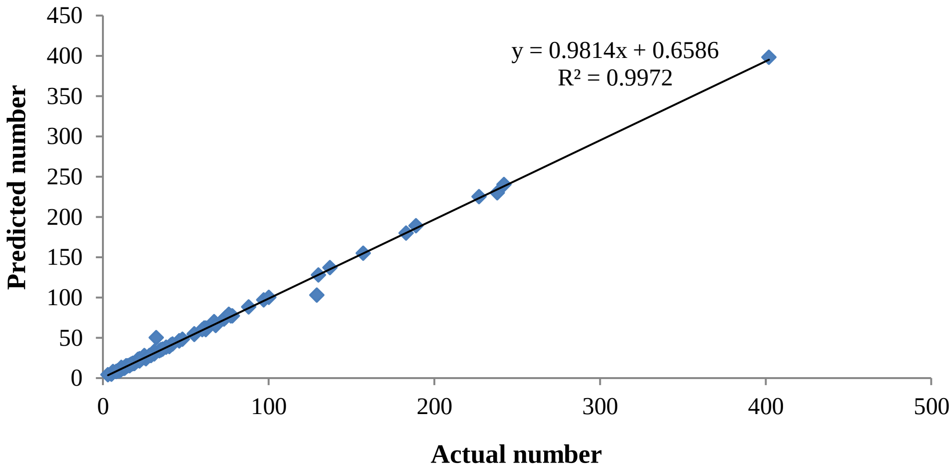
نتایج و بحث

تعداد زنجرک‌های پسته چسبیده به کارت‌های زرد بین ۸ تـا ۴۰۲ عدد در روی هر کارت متغیر بود، که به‌طور متوسط ۴۶ عدد *I. Stali* در روی هر کارت زرد وجود داشت. بـا اسـتفاده از الگـوریتم پـردازش تصویر طراحی شده به‌طور خودکار تراکم زنجرک‌های پسـته بـر روی کارت‌های زرد چسبناک تخمین زده شد. تراکم‌های تخمین زده شـده نمونه‌ها به‌وسیله سیستم پردازش تصویر با مقـادیر واقعـی هـم‌خـوانی خوبی داشتند. ضریب تعیین[۷] بین تعداد *I. Stali* چسبیده به کارت زرد و تعداد *I. Stali* تخمین زده شده به وسیله پردازش تصـویر ۰/۹۹۷۲ بود (شکل ۴). بنابراین نرخ تشخیص الگوریتم پردازش تصویر طراحی شده ۹۹/۷۲ درصد می‌باشد. در مقایسه با کار کیائو و همکاران (Qiao

1- Cconfusion matrix
2- Receiver Operating Characteristic (ROC)
3- Sensitivity
4- Specificity
5- Accuracy
6- Area under the curve (AUC)

7- Coefficient of determination (R^2)

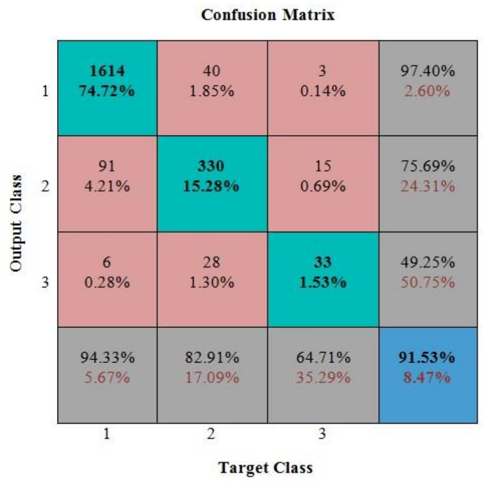
et al., 2008) که گروه‌ها براساس تعداد سفیدبالک‌های در دام افتاده: کمتر از ۱۰(تراکم کم)، ۱۰ تا ۵۰ (تراکم متوسط) و بیش از ۵۰ (تراکم زیاد) تقسیم‌بندی شده بودند، ضریب تعیین (R^2) بین داده‌های برآورد شده و واقعی به‌ترتیب ۰/۹۸ و ۰/۹۶ برای گروه‌های با تراکم متوسط و زیاد بود. با این حال، در تراکمِ کم، ضریب تعیین (R^2) تنها ۰/۶۵۶ بود. ضریب تعیین کیائو برای کل سفیدبالک‌ها ۰/۸۶۵ بود. همان‌طور که مشاهده می‌شود ضریب تعیین تحقیق حاضر (R^2=۰/۹۹۷۲)، که روی کل کارت‌ها با تراکم‌های مختلف زنجرک پسته انجام گرفته است، بسیار بالاتر از ضریب تعیین کیائو می‌باشد.



شکل ٤– نمودار رگرسیونی بین تعداد زنجرک‌های به دام افتاده مشاهده شده (محور افقی) و تعداد زنجرک‌های تشخیص داده شده به‌وسیله الگوریتم پردازش تصویر (محور عمودی)

Fig.4. Regression graph between number of *I. Stali* observed (horizontal axis) and number of *I. Stali* identified by image processing algorithm (vertical axis)

ماتریس اغتشاش و دقت طبقه‌بندی مربوط به داده‌های آزمون جهت بررسی عملکرد و کارآیی سیستم طبقه‌بند به‌ترتیب در شکل ۵ و جدول ۳ ارائه شده است. در جدول ۳ سه دسته زنجرک پسته، *Anthaxia* Sp. و اشیاء متفرقه وجود دارد که اشیاء متفرقه ممکن است حشرات متفرقه دیگر یا گرد و خاک باشند. همان‌طور که از جدول ۳ مشاهده می‌گردد، حشره هدف که زنجرک پسته می‌باشد، دارای کمترین درصد تشخیص اشتباه (۲/۶۰ درصد) بوده و دقت طبقه‌بندی این الگوریتم، در صورتی‌که بخواهیم حشرات جذب شده روی کارت زرد را به سه دسته طبقه‌بندی نماییم، ۹۱/۵۳ درصد می‌باشد، که دقت قابل قبولی است.



شکل ۵– ماتریس اغتشاش بر روی مجموعه آزمون برای سه کلاس مختلف

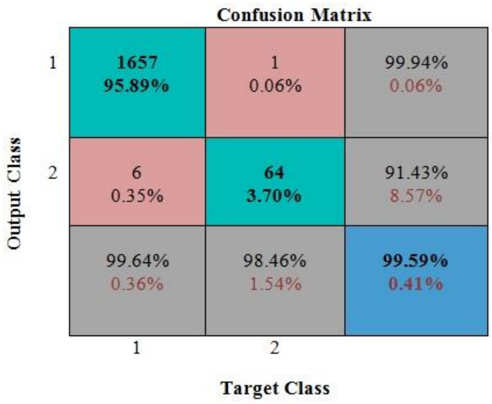
Fig.5. The confusion matrix on the test set for three different classes

جدول ۳- ماتریس اغتشاش و میزان دقت سیستم طبقه‌بندی بر روی مجموعه آزمون برای سه کلاس مختلف

Table 3- The confusion matrix and accuracy level of the classification system on the test set for three different classes

Classes **کلاس‌ها**	***Idiocerus stali*** **زنجرک پسته**	**Miscellaneous objects** **اشیاء متفرقه**	***Anthaxia* Sp.** **سوسک چوب‌خوار قرمز پسته**	**Total** **کل**	**Percentage of misdiagnosis** **درصد تشخیص اشتباه**	**Total percentage of correct diagnosis** **در صد کل تشخیص درست**
Idiocerus stali زنجرک پسته	**1614**	40	3	1657	2.60	**91.53**
Miscellaneous objects اشیاء متفرقه	91	**330**	15	436	24.31	
Anthaxia Sp. سوسک چوب‌خوار قرمز پسته	6	28	**33**	67	50.75	

اما با توجه به این‌که هدف از این تحقیق شناسایی زنجرک پسته بود، لذا با استفاده از این الگوریتم داده‌ها بـه دو دسته حشره هدف یعنی زنجرک پسته و *Anthaxia* Sp. طبقه‌بندی شدند. تعداد حشره زنجرک پسته روی کارت زرد ۴۱۴۹ عـدد و حشـره *Anthaxia* Sp.، ۱۷۱ عدد بود که در مجموع ۴۳۲۰ حشره بودند و سیستم از ۴۰ درصد این تعداد حشره یعنی ۱۷۲۸ حشره به‌صورت تصادفی بـرای آزمـون و اعتبارسنجی استفاده نمـود. همـان‌گونـه کـه در شـکل ۶ و جـدول ۴ مشاهده می‌شود، درصد تشخیص اشتباه زنجـرک پسـته ۰/۰۶ درصـد می‌باشد و دقت الگوریتم برای شناسایی زنجرک پسته در طبقـه‌بنـدی داده‌ها به دو دسته، ۹۹/۵۹ درصد می‌باشد.



شکل ٦- ماتریس اغتشاش بر روی مجموعه آزمون برای دو کلاس مختلف

Fig.6. The confusion matrix on the test set for two different classes

جدول ٤- ماتریس اغتشاش و میزان دقت سیستم طبقه‌بندی بر روی مجموعه آزمون برای دو کلاس مختلف

Table 4- The confusion matrix and accuracy level of the classification system on the test set for two different classes

Classes **کلاس‌ها**	***I. stali*** **زنجرک پسته**	***Anthaxia* Sp.** **سوسک چوب‌خوار قرمز پسته**	**Total** **کل**	**Percentage of misdiagnosis** **درصد تشخیص اشتباه**	**Total percentage of correct diagnosis** **درصد کل تشخیص درست**
I. stali زنجرک پسته	**1657**	1	1658	0.06	**99.59**
Anthaxia Sp. سوسک چوب‌خوار قرمز پسته	6	**64**	70	8.57	

در مقایسه این نتایج با نتایج تحقیق چو و همکاران (Cho et al., 2007) مشاهده می‌شود که در کار ایشان که سه حشره مختلف سفیدبالک، شته و تریپس را مورد شناسایی قرار دادند و نرخ تشخیص الگوریتم به‌ترتیب برابر با ۹۳/۶۳ درصد، ۹۲/۷۳ درصد و ۸۸/۹ درصد بود و این در حالی است که نرخ تشخیص سیستم طبقه‌بند طراحی شده در تحقیق حاضر برای هر دو نوع حشره به دام افتاده یکسان و برابر ۹۹/۵۹ درصد بود.

در مقایسه نتایج این تحقیق با تحقیق بویسارد و همکاران (Boissard et al., 2008) که ایشان از سیستم پردازش تصویر به‌صورت عکس‌برداری در محل و در شرایط نور طبیعی، برای شناسایی سفیدبالک استفاده نمودند، مشاهده می‌شود که دقت تشخیص الگوریتم شناسایی آن‌ها در مقایسه با شمارش چشمی، ۸۳ درصد بود، در حالی که دقت تشخیص الگوریتم شناسایی تحقیق حاضر ۹۹/۵۹ درصد می‌باشد.

در مقایسه این نتایج با نتایج تحقیق کیائو و همکاران (Qiao et al., 2008)، مشاهده می‌شود که در کار ایشان که داده‌ها را به سه زیردسته تقسیم کرده بود، برای دسته تراکم متوسط و زیاد نرخ تشخیص به‌ترتیب برابر با ۹۵/۲ و ۹۴/۶درصد بود. از طرفی در تراکم کم (کمتر از ۱۰ حشره به دام افتاده)، نرخ تشخیص آن نیز ۷۲/۹درصد بود و این در حالی است که نرخ تشخیص سیستم طبقه‌بند طراحی شده در تحقیق حاضر برای تراکم‌های مختلف حشرات به دام افتاده یکسان و برابر ۹۹/۵۹ درصد بود.

در مقایسه این نتایج با نتایج تحقیق حیدری و امیری پریان (Heidari and Amiri Parian, 2019)، که ایشان در تحقیق خود سفیدبالک و تریپس را به‌ترتیب با دقت ۹۴/۵ و ۸۷/۴ درصد شناسایی نمودند و این در حالی است که دقت تحقیق حاضر برای شناسایی زنجرک پسته، ۹۹/۵۹ درصد می‌باشد.

جدول ۵ مقادیر حساسیت، خاصیت و دقت مربوط به سیستم طبقه‌بندی برای حالت دو کلاس را نشان می‌دهد. نحوه محاسبه مقادیر موجود در جدول ۵ با استفاده از روابط (۲) تا (۴) بوده که در آن‌ها، به‌عنوان مثال برای زنجرک پسته مقادیر TP برابر ۱۶۵۷، TN برابر ۶۴، FN برابر ۱ و FP برابر ۶ از جدول ۴ به‌دست آمدند. همانطور که در جدول ۵ مشاهده می‌شود، نتایج نشان می‌دهد که روش هیبرید عصبی–ازدحام ذرات در شناسایی زنجرک پسته دارای حساسیت ۹۹/۹۴ می‌باشد و این بدان معنی است که سیستم طراحی شده ۹۹/۹۴ درصد حشره زنجرک پسته را درست تشخیص داده است. به‌طور کلی حساسیت بالا بدین معنی است که نمونه‌های بیشتری به‌طور صحیح طبقه‌بندی شده‌اند. از طرفی خاصیت سیستم برای همین حشره برابر با ۹۱/۴۳ به‌دست آمد و این بدان معنی است که سیستم طبقه‌بند فقط ۸/۵۷ درصد حشره *Anthaxia* Sp. و نقاط سیاه رنگ ناشی از گرد و خاک روی کارت‌های زرد رنگ را به‌صورت اشتباه زنجرک پسته تشخیص داده است. در نهایت مشاهده می‌گردد که حشره زنجرک پسته با دقت ۹۹/۵۹ درصد طبقه‌بندی شده است.

جدول ۵– مقادیر حساسیت، خاصیت و دقت مربوطبه سیستم طبقه‌بندی برای حالت دو کلاس

Table 5- The sensitivity, specificity and accuracy values of the classification system for the two classes

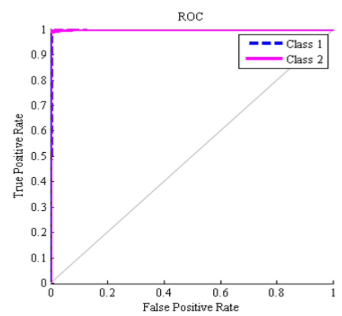
Classes کلاس‌ها	The hybrid method of ANN-PSO روش هیبرید شبکه عصبی مصنوعی- بهینه‌سازی ازدحام ذرات Sensitivity حساسیت	Accuracy دقت	Specificity خاصیت
I. stali زنجرک پسته	99.94	99.59	91.43
Anthaxia Sp. سوسک چوب‌خوار قرمز پسته	91.43	99.59	99.94

جدول ٦– مقادیر مربوط به معیارهای مختلف خطا، درصد طبقه‌بندی صحیح و سطوح زیر منحنی ROC برای حالت ۲ کلاس

Table 6- The values for the different error criteria, the percentage of the correct classification and the Area under the ROC curve for the 2 classes

AUC(2) سطح زیر منحنی کلاس ۲	AUC(1) سطح زیر منحنی کلاس ۱	OCA دقت طبقه‌بندی کلی	MAE میانگین خطای مطلق	RMSE ریشه میانگین مربعات خطا	MSE میانگین مربعات خطا
0.99962	0.99969	99.59	0.013	0.0598	0.0036

همان‌گونه که در بخش مواد و روش‌ها ذکر گردید، از مجموع ۳۷۷ خصوصیت استخراجی از هر شیء، با استفاده از روش هیبرید شبکه عصبی مصنوعی–الگوریتم بهینه‌سازی ازدحام ذرات (ANN-PSO)، ۶ خصوصیت که میانگین مربعات خطای کمتری داشتند، به‌عنوان خصوصیات مؤثر انتخاب گردید و به‌عنوان ورودی شبکه عصبی مصنوعی برای طبقه‌بندی اعمال شدند. خصوصیات مؤثر عبارتند از: شاخص رنگی برای پوشش گیاهی استخراجی مربوط به فضای رنگی HSL، شاخص تفاضل نرمال شده مربوط به فضای رنگی LCH، کانال خاکستری مربوط به فضای رنگی YCbCr، شاخص مؤلفه دوم منهای مؤلفه سوم مربوط به فضای رنگی YCbCr، مساحت و میانگین مؤلفه‌های اول، دوم و سوم فضای رنگی Luv. تحلیل منحنی ROC جهت مشخص کردن حساسیت و خاصیت سیستم طبقه‌بند به‌کار برده می‌شود. محور افقی این منحنی نرخ مثبت کاذب FPR[۱] یا همان یک منهای خاصیت[۲] است و محور عمودی آن نرخ مثبت واقعی TPR[۳] یا همان حساسیت می‌باشد (Panduranga Vitala *et al*., 2015). نرخ FPR عبارت است از عنصر روی قطر فرعی[۴] تقسیم بر مجموع عناصر روی ردیف مربوطه در ماتریس اغتشاش. نرخ TPR برابر است با عنصر روی قطر اصلی برای هر کلاس که درست طبقه‌بندی شده، تقسیم بر مجموع عناصر روی ردیف مربوطه که برابر حساسیت است (Wisaeng, 2013). به تعداد کلاس‌ها منحنی وجود دارد. نمودار ROC مربوط به طبقه‌بندی شبکه عصبی مصنوعی برای دو کلاس در شکل ۷ نشان داده شده است.



شکل ۷– نمودار ROC مربوط به طبقه‌بندی شبکه عصبی مصنوعی برای ۲ کلاس مختلف، (کلاس ۱ *Anthaxia* Sp.، کلاس ۲ زنجرک پسته)

Fig.7. The ROC curve for Artificial Neural Network classification for two different classes, (Class 1 *Anthaxia* Sp., Class 2 *Idiocerous stali*)

همانطور که در شکل ۷ مشاهده می‌شود هر دو کلاس با فاصله خیلی زیادی از نیم‌ساز واقع شده‌اند، این بدان معنی است که سیستم طبقه‌بندی شبکه عصبی مصنوعی، هر دو کلاس را به خوبی طبقه‌بندی نموده است. معیارهای مختلف خطا، درصد طبقه‌بندی صحیح و سطوح زیر منحنی ROC برای حالت ۲ کلاس مختلف نیز در جدول ۶ نشان داده شده است. همچنین در شکل ۷ و جدول ۶ سطح زیر منحنی در هر دو کلاس بسیار بیشتر از سطح بالای منحنی‌ها بوده و طبق جدول ۲ در ناحیه دقت تشخیص عالی می‌باشد و این یعنی طبقه‌بند شبکه عصبی مصنوعی با دقت بالا نمونه‌های هر دو کلاس را طبقه‌بندی کرده است. نتایج نشان می‌دهد که دقت طبقه‌بندی کلی[۵] برای دو کلاس مختلف ۹۹/۵۹ درصد می‌باشد. سایر معیارهای میانگین مربعات خطا (MSE)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) نسبت به حالت سه کلاس بسیار پایین‌تر می‌باشد، که هر قدر این پارامترها کوچک‌تر باشند، نشان‌دهنده طراحی بهتر الگوریتم طبقه‌بندی می‌باشد.

نتیجه‌گیری

برای توسعه الگوریتم پردازش تصویر، جهت شناسایی زنجرک پسته، از خصوصیات رنگی و شکلی اشیاء (حشره زنجرک پسته و سایر حشره‌های غیر هدف و متفرقه) موجود در تصاویر مربوط به کارت زرد چسبناک، استفاده شد. از ۱۷ فضای رنگی، ۳۵۷ خصوصیت رنگی و ۲۰ خصوصیت شکلی برای شناسایی زنجرک پسته به‌وسیله الگوریتم پردازش تصویر، استخراج شد. از روش هیبرید شبکه عصبی مصنوعی– الگوریتم بهینه‌سازی ازدحام ذرات برای انتخاب خصوصیات مؤثر مثل شاخص رنگی برای پوشش گیاهی استخراجی مربوط به فضای رنگی HSL، شاخص تفاضل نرمال شده مربوط به فضای رنگی LCH، کانال خاکستری مربوط به فضای رنگی YCbCr، شاخص مؤلفه دوم منهای مؤلفه سوم مربوط به فضائ رنگی YCbCr، مساحت و میانگین مؤلفه‌های اول، دوم و سوم فضای رنگی Luv، جهت طبقه‌بندی حشرات استفاده گردید. شبکه عصبی پرسپترون چندلایه، با سه لایه پنهان ۳۸ نورونی و سه تابع انتقال satlins، tansig و tansig به‌ترتیب در لایه‌های اول تا سوم و تابع آموزش شبکه پس‌انتشار برگشتی trainlm و تابع یادگیری وزن/بایاس پس‌انتشار برگشتی learnsom برای طبقه‌بندی داده‌ها به دو کلاس مورد استفاده قرار گرفت. نرخ شناسایی الگوریتم پردازش تصویر طراحی شده، ۹۹/۷۲درصد کل اشیاء (زنجرک پسته و سایر حشره‌های غیر هدف و متفرقه) می‌باشد. شبکه‌های عصبی مصنوعی، توانایی طبقه‌بندی حشرات به سه کلاس (زنجرک پسته، سوسک

1- False Positive Rate (FPR)
2 –1-specificity
3- True Positive Rate (TPR)
4- Non-diagonal elements

5- Overall Classification Accuracy (OCA)

چوب‌خوار قرمز پسته وسایر حشره‌های غیر هدف و متفرقه) و دو کلاس زنجرک پسته و .Anthaxia Sp به‌ترتیب با دقت ۹۱/۵۳ و ۹۹/۵۹ درصد را دارند. این امر بیانگر آن است که این الگوریتم می‌تواند روی سیستم ماشین بینایی پیاده شود و در آینده در ساختمان ربات‌های کشاورزی از آن بهره گرفت.

References

1. Baiocchi, D. 2013. The *Anthaxia* (*Anthaxia*) manca (Linnaeus, 1767) species-group in Iran, with description of a new species and a new synonymy (Coleoptera: Buprestidae). Zootaxa 3616: 455-481.
2. Barbedo, J. G. A. 2014. Using digital image processing for counting whiteflies on soybean leaves. Journal of Asia-Pacific Entomology 17: 685-694.
3. Boissard, P., V. Martin, and S. Moisan. 2008. A cognitive vision approach to early pest detection in greenhouse crops. Computers and Electronics in Agriculture 62: 81-93.
4. Cho, J., J. Choi, M. Qiao, C.-W. Ji, H.-Y. Kim, K.-B. Uhm, and T.-S. Chon. 2007. Automatic identification of whiteflies, aphids and thrips in greenhouse based on image analysis. International Journal of Mathematics and Computers in Simulation 7 (1): 46-53.
5. Espinoza, K., D. L. Valera, J. A. Torres, A. López, and F. D. Molina-Aiz. 2016. Combination of image processing and artificial neural networks as a novel approach for the identification of *Bemisia tabaci* and *Frankliniella occidentalis* on sticky traps in greenhouse agriculture. Computers and Electronics in Agriculture 127: 495-505.
6. FAO. 2017. Food and agriculture organization of the United Nations. Retrieved May 16, 2019; Available at: http://fao.org/faostat/en/#data.
7. Ghaiwat, S. N. and P. Arora. 2014. Detection and classification of plant leaf diseases using image processing techniques: A review. International Journal of Recent Advances in Engineering and Technology 2 (3): 1-7.
8. Gonzalez, R. C., and R. E. Woods. 2018. Digital Image Processing, 4th ed. Pearson, 1306 pp., New York, USA.
9. Gonzalez, R. C., R. E. Woods, and S. L. Eddins. 2004. Digital Image Processing Using MATLAB, (Second ed.).USA. New Jersey: Pearson Prentice Hall.
10. Heidari, A., and J. Amiri Parian. 2019. Identification and Counting of Two Important Greenhouse Pests by Image Processing, Case Study: Whitefly and Thrips. Journal of Agricultural Machinery 9 (2): 309-320. (In Persian).
11. Jalilvand, N. and S. Kashani-Zadeh. 2013. Study on the Biology of *Idiocerus stali* in Qazvin Climate. Agricultural Research and Natural Resources Journal 3 (15): 22-30. (In Persian).
12. Karbasi, A. R., and A. H. Taohidi. 2015. Factors Affecting Iranian Pistachio Export. Agricultural Economics Research 7 (1): 91-112. (In Persian).
13. Kazmi, W., F. J. Garcia-Ruiz, J. Nielsen, J. Rasmussen, and H. J. Andersen. 2015. Detecting creeping thistle in sugar beet fields using vegetation indices. Computers and Electronics in Agriculture 112: 10-19.
14. Kennedy, J., and R. Eberhart. 1995. Particle Swarm Optimization, 1942-1948 pp., Proceedings of the International Conference on Neural Networks, 27 Nov-1 Dec. 1995, Perth, Australia.
15. Kia, M. 2009. Neural Networks, (Second ed.) Tehran, Iran: Kian Rayaneh Sabz Publisher. 232 pp. (In Persian).
16. Mehrnejad, M. R. 2001. The current status of pistachio pests in Iran. In: Proceedings of the XI GREMPA Seminar on Pistachios and Almonds. (Cahiers Options Méditerranéennes; n. 56). Zaragoza: CIHEAM. pp. 315-322. Retrieved November 21, Available at: http://om.ciheam.org/option.php?IDOM=769.
17. Modarres Awal, M. 2009. Classification of insects, (1st ed.). Mashhad, Iran: Ferdowsi University Publisher. (In Persian).
18. Mozaffarian, F., and M. R. Wilson. 2016. A checklist of the leafhoppers of Iran (Hemiptera: Auchenorrhyncha: Cicadellidae). Zootaxa, 4062 (1): 1-63.
19. Panduranga Vitala, T., G. S. V. Prasada Rajub, K. Sreeramamurthy, and V. P. Venkata Charan. 2015. A Probabilistic Neural Network Approach for Classification of Datasets Collected From North Coastal Districts of AP, India Using MatLab 715-721 pp., Proceedings of the International Conference on Computer, Communication and Convergence (ICCC 2015), Odisha, India.
20. Qiao, M., J. Lim, C. W. Ji, B. K. Chung, H. Y. Kim, K. B. Uhm, C. S. Myung, J. Cho, T. S. Chon, D. Herák, A. K., A. Sedláček, and G. Gűrdil. 2008. Density estimation of *Bemisia tabaci* (Hemiptera: Aleyrodidae) in a greenhouse using sticky traps in conjunction with an image processing system. Journal of Asia-Pacific Entomology 11: 25-29.
21. Šimundić, A. M. 2009. Measures of Diagnostic Accuracy: Basic Definitions. The Journal of the International Federation of Clinical Chemistry and Laboratory Medicine (EJIFCC) 19: 203-211.
22. Solomon, C., and T. Breckon. 2011. Fundamentals of Digital Image Processing. (First ed.). West Sussex, UK: John Wiley & Sons, Ltd, Publication, 328 pp.
23. Wisaeng, K. 2013. A Comparison of Decision Tree Algorithms for UCI Repository Classification. International Journal of Engineering Trends and Technology (IJETT) 4: 3393-3397.